

激光与光电子学进展

基于分数阶微分的土壤有机质含量高光谱反演研究

李武耀¹, 买买提·沙吾提^{1,2,3*}, 买合木提·巴拉提^{1,2,3}¹新疆大学地理与遥感科学学院, 新疆 乌鲁木齐 830046;²新疆绿洲生态重点实验室, 新疆 乌鲁木齐 830046;³智慧城市与环境建模自治区普通高校重点实验室, 新疆 乌鲁木齐 830046

摘要 土壤有机质(SOM)对改善干旱区土地盐碱化、沙漠化和草场退化等环境问题发挥着重要作用。为了探索分数阶微分方法在SOM高光谱反演的可行性,以渭干河-库车河绿洲73个土壤样本为研究对象,通过测定其SOM含量与光谱反射率,利用0.2阶微分为步长,进行0~2阶分数阶微分的数学变换,分析分数阶处理光谱与SOM含量间的相关性,运用支持向量机回归、偏最小二乘回归和随机森林(RF)等方法对SOM含量进行定量反演。结果表明:采用RF的1.2阶微分建立的SOM含量反演模型预测精度最高,决定系数为0.93,均方根误差为1.62,相对分析误差为3.65。研究结果为精准反演该地区的SOM提供了依据,也为其他地区的SOM反演提供一定的参考。

关键词 分数阶微分; 高光谱; 土壤有机质; 模型估测

中图分类号 TP79 文献标志码 A

DOI: 10.3788/LOP220715

Fractional Differential-Based Hyperspectral Inversion of Soil Organic Matter Content

Li Wuyao^{1,2,3}, Mamat Sawut^{1,2,3*}, Maihemuti Balati^{1,2,3}¹College of Geography and Remote Sensing Science, Xinjiang University, Urumqi 830046, Xinjiang, China;²Xinjiang Key Laboratory of Oasis Ecology, Urumqi 830046, Xinjiang, China;³Key Laboratory of Smart City and Environment Modelling of Higher Education Institute, Urumqi 830046, Xinjiang, China

Abstract Soil organic matter (SOM) plays an important role in ameliorating environmental problems such as land salinization, desertification, and grassland degradation in arid areas. To explore the feasibility of the fractional differential method in hyperspectral SOM inversion, 73 soil samples from Weigan River to Kuqa River oasis were considered as research objects. By measuring the SOM content and spectral reflectance, the mathematical transformation of a fractional differential of order 0–2 was performed using a 0.2-order differential as the step size. Further, the correlation between the fractional processing spectrum and SOM content was analyzed. Support vector machine regression, partial least squares regression, and random forest (RF) methods were used to quantitatively invert the SOM content. The results reveal that the prediction accuracy of the SOM inversion model established by the 1.2 RF derivative is the highest, with Coefficient of determination of 0.93, Root mean squared error of 1.62, and Relative percent difference of 3.65. These results can provide a basis for accurate inversion of SOM in this study area, and they also have a certain reference significance for inversion of SOM in other areas.

Key words fractional differentiation; hyperspectrum; soil organic matter; model to estimation

1 引言

土壤有机质(Soil organic matter, SOM)是土壤肥力的物质基础,也是土壤形成发育的主要标志,还是土

壤中最关键的组成部分之一^[1]。以往采用化学分析方法测定SOM含量,具有耗时长和费用高等缺点,高光谱的发展为该问题提供了解决方法,逐渐成为了监测区域土地资源的新方法^[2-3]。

收稿日期: 2022-02-14; 修回日期: 2022-03-14; 录用日期: 2022-03-18; 网络首发日期: 2022-03-28

基金项目: 新疆自然科学基金(自然科学基金)联合基金(2021D01C055)

通信作者: *korxat@xju.edu.cn

据以往研究可知,土壤光谱反射率和 SOM 含量具有明显的相关性,所以利用土壤光谱特征的差异来反映 SOM 含量就尤为重要,通过构建多种光谱指数和对土壤光谱进行数学变换,为 SOM 含量的高光谱反演研究提供了有效的途径^[4-9]。目前 SOM 的光谱反演方法主要有多元线性回归(Multiple linear regression, MLR)^[5,10]、偏最小二乘回归(Partial least squares regression, PLSR)^[6,8,10,19]、随机森林(Random forest, RF)^[7]、支持向量机回归(Support vector machine regression, SVR)^[7-8]等,这些方法在特定的研究区域均取得了较好的效果。此外,大量研究表明,光谱数据预处理和特征波段的筛选成为提高模型精度的关键,如对数^[8]、倒数^[8]、对数的倒数^[9]、倒数的对数^[9]、一阶微分^[8,10]和二阶微分^[10-11]等数学变换,可以有效提高预测精度,其中,一阶微分和二阶微分等整数阶微分数学变换形式,取得了较好的效果。然而,整数阶微分数学变换形式对土壤光谱数据处理时中间空缺较多,可能会导致具体的信息遗漏,因此,为了细化光谱特征对 SOM 预测精度的影响,利用分数阶微分的方法对光谱数据进行潜在信息的挖掘是非常有必要的。田安红等^[12]使用分数阶微分的方法对新疆干旱区盐渍土的电导率进行研究时发现在 1.5 阶处估算效果最佳,王小平等^[13]在对艾比湖的 SOM 含量进行估测时使用分数阶微分方法,发现在 1.2 阶处取得了良好的效果,赵慧等^[14]使用分数阶微分的方法对博斯腾湖滨带绿洲土壤电导率估算时发现在 1.6 阶效果较好,赵启东等^[15]使用分数阶微分的方法对渭库绿洲的土壤有机碳进行估测时,发现在 1.6 阶估算精度最佳。这些研究表明经过分数阶微分方法处理之后预测模型精度有一定的提升。因此,本文通过测定研究区域 SOM 含量与光谱数据,分析土壤光谱与 SOM 的相关性,确定出最佳光谱的数学变换形式和模型,为利用可见-近红外光谱技术快速地估算干旱区绿洲 SOM 含量提供技术支持。

2 材料与方 法

2.1 研究区概况

渭干河-库车河三角洲绿洲(即渭库绿洲)属于阿克苏地区,主要位于塔里木盆地北部的山前扇形冲积平原,是新疆非常重要的粮棉基地。该地区属于温带大陆性气候,多年年均气温为 10.5~11.4℃,多年平均降水量为 43.1~51.6 mm^[15]。主要的自然植被类型有胡杨、柽柳和梭梭等,土壤类型以沙壤和轻壤为主,土壤构成物颗粒细,透水性差,从而导致该地的土壤盐渍化现象较为严重。

2.2 土壤样本的采集与处理

在考虑渭库绿洲土地の利用方式基础上,根据土壤空间分布特征,2019年8月本团队在该研究区使用网格采样法采集深度为 0~10 cm 的表层土壤,共计 73 份土壤样品,每个土壤样品的质量大约为 500 g。样

本带回实验室风干、研磨,过 100 目(0.15 mm)筛后进行 SOM 含量测定,采用重铬酸钾容量法-外加热法^[16]。研究区土壤样本点分布如图 1 所示。




图 1 研究区地理位置及采样点分布

Fig. 1 Geographical position of study area and distribution of sampling

2.3 光谱数据的测定及处理

使用 ASD FieldSpec3 便携式光谱仪获取土壤样本的光谱数据。选择晴朗无云的天气,测定时间为北京时间 12:00—16:00,太阳高度角为 45°~50°。测量过程中需一直正对着太阳,测取波长为 325~1050 nm 的光谱曲线,采样间隔为 1 nm。测定过程中仪器的传感器探头保持垂直向下,且应与样品表面之间相隔的距离约为 15 cm,测定前经白板校正。测定中为了保证实验数据的准确率,每个土样都用光谱仪扫描 8 s,测量 10 次,在测完 10 次后做一次白板标定,每一波长的土壤光谱反射率值通过 ViewSpec PRO 软件计算 10 条曲线的平均值求得^[17]。

为了探索分数阶微分在 SOM 高光谱反演的可行性,对光谱数据进行 Grünwald-Letnikov(G-L)分数阶微分一元函数差分,在 Matlab 中实现对平滑后光谱反射率数据的 0~2 阶微分(以 0.2 阶为步长)的计算,处理后的光谱数据将作为下一步筛选 SOM 敏感波段的依据。分数阶微分是基于 G-L 一元函数差分实现的^[11-15],是对整数阶微分的扩展,其具体计算为

$$d^b f(a) = \lim_{h \rightarrow 0} \frac{1}{g^b} \sum_{m=0}^{\lfloor (c-d)/g \rfloor} (-1)^m \frac{\Gamma(b+1)}{e! \Gamma(b-e+1)} f(a-eg), \quad (1)$$

式中: c 为高光谱的波长,nm; $f(a)$ 为 a 的函数; b 为分数阶阶次; g 为步长; c 为分数阶微分的上限; d 为分数阶微分的下限; $e \in [0, \frac{c-d}{g}]$, Γ 为 Gamma 函数。选用 g 为 1, c 和 d 是起止波长,令 $c-d=e$, $m \in [0, e]$,式(1)可表示为

$$\frac{d^b f(a)}{da^b} \approx f(a) + (-b)f(a-1) + \frac{(-b)(-b+1)}{2} f(a-2) + \dots + \frac{\Gamma(-b+1)}{e! \Gamma(-b+e+1)} f(a-e) \quad (2)$$

由式(2)可知,当阶次为1时, $a+1$ 处的微分值仅与 a 处的微分值相关,但阶次为分数时, $a+1$ 处的微分值同时考虑了前面所有 a 的影响。因此,以分数阶微分对光谱进行处理可保留更多的光谱特征。

2.4 模型建立与验证

2.4.1 模型建立

将73个土壤样本按照2:1的比例随机抽取49个样本用于建模,剩下的24个样本用于验证。利用Matlab软件,运用SVR^[8]、PLSR^[10]和RF^[12]建立基于高光谱的有机质预测模型。运用典型相关分析的方法,对经过分数阶微分的光谱反射率逐波段与SOM含量进行相关性分析,并对其相关系数在 $P=0.05$ 水平上进行显著性检验,通过显著性检验的波段即为显著性波段,并作为建立反演模型的输入参数。

2.4.2 精度验证

模型的精度主要由决定系数(R^2)、均方根误差(RMSE)和相对分析误差(RPD)3个指标来评判^[20]。 R^2 反映模型的稳定性, R^2 越接近于1,说明模型的稳定性越好、拟合程度越高。RMSE用来检验模型的准确性,其值越小说明精度越高。RPD用来判断模型的预测能力,分为3个等级,分别为较好($RPD \geq 2.0$)、尚可($1.4 \leq RPD < 2.0$)和无估测能力($RPD < 1.4$)。1:1线用于检验实测值、预测值所构成的散点偏离 $y=x$ 线的程度。

3 结果与分析

3.1 SOM含量统计特征

研究区各数据集SOM的描述性统计分析如表1所示。由表1可知,研究区总样本集的SOM含量为2.742~25.416 $\text{g} \cdot \text{kg}^{-1}$,表明取样点的SOM含量相差较大。其中,SOM均值为11.958 $\text{g} \cdot \text{kg}^{-1}$,根据全国第二次土壤普查及有关标准^[21],属于四级,即缺乏。总样

表1 研究区域样本SOM含量统计特征

Sample type	Quantity	Max	Min	Mean	Standard deviation	CV / %
Calibration	49	25.416	2.758	11.602	5.436	46.86
Validation	24	24.133	2.742	12.531	5.810	46.37
Totally	73	25.416	2.742	11.959	5.601	46.84

本集的变异系数为46.84%,属于中等变异,表明SOM含量较离散。

3.2 不同有机质含量土壤光谱特征

为分析SOM与土壤高光谱的响应特性,将所有的SOM样本分4个等级,并研究了不同SOM水平下的原始光谱,结果如图2所示。由图2可知,在不同SOM水平下,土壤样本光谱反射率不同,但其反射率曲线整体变化趋势基本相同。在整个波段范围内,除有机质含量少于6 $\text{g} \cdot \text{kg}^{-1}$ 外,随着SOM含量的增加,光谱反射率整体呈下降趋势,其中在400~600 nm光谱曲线呈明显上升趋势;在600~1075 nm上升趋势比较平稳,589 nm、617 nm和935 nm出现了反射率峰值,760 nm有明显的吸收谷。这也证明了SOM对可见光波段的敏感性。




图2 不同有机质含量下土壤反射率光谱曲线
Fig. 2 Reflectance curves of soil with different organic matter contents

3.3 SOM与光谱相关性分析

将土壤的光谱反射率进行分数阶微分处理之后与有机质含量进行相关性分析,并在 $P=0.05$ 水平下作相关系数 r 的显著性检验,结果如表2所示。由表2可知:1) 在得到0~0.8阶的微分变换中显著性水平低,敏感波段很少;2) 在1~2阶的微分变换中都普遍存在464 nm、597 nm、648 nm、723 nm和792 nm等敏感波段,这些波段与有机质含量相关性较高,其中,1阶微分、1.2阶微分和1.4阶微分敏感波段位置基本一致,1.6阶微分、1.8阶微分和2阶微分的敏感波段位置也大体相同。在1~2阶微分敏感波段数量先增加后减少,尤其是在1.6阶微分时敏感波段数量最多。为了进一步研究,选取1~2阶微分中相关性最强的8个敏感波段用于建模和验证,如图3所示。

表 2 分数阶微分下的 SOM 特征波段

Table 2 Characteristic bands of SOM under fractional differentiation

Spectral transformation	Characteristic band /nm	Number of wavelengths	r
0	/	0	/
0.2	/	0	/
0.4	/	0	/
0.6	/	0	/
0.8	399,435	2	0.293,0.316
1	588,597,630,648,675,792,855,1013	8	0.308,0.323,0.290,-0.286,-0.308,-0.350,-0.291,0.290
1.2	407,464,588,597,648,671,675,723,792,1013	10	0.285,-0.312,0.290,0.319,-0.310,0.280,-0.287,-0.293,-0.368,0.353
1.4	407,425,464,597,648,671,723,775,792,965,1013	11	0.316,-0.294,-0.335,0.315,-0.308,0.287,-0.307,0.282,-0.372,-0.278,0.283
1.6	387,407,425,464,597,648,671,676,723,775,792,965	12	0.296,0.343,-0.283,-0.343,0.305,-0.300,0.285,0.278,-0.311,0.298,-0.366,-0.278
1.8	387,407,464,597,648,671,676,723,775,792,797	11	0.309,0.364,-0.347,0.288,-0.291,0.278,0.289,-0.307,0.309,-0.353,0.277
2	387,407,464,648,676,723,775,792,797	9	0.303,0.377,-0.349,-0.282,0.293,-0.297,0.314,-0.336,0.278

注：表中“/”代表在 0.05 水平下没有特征波段

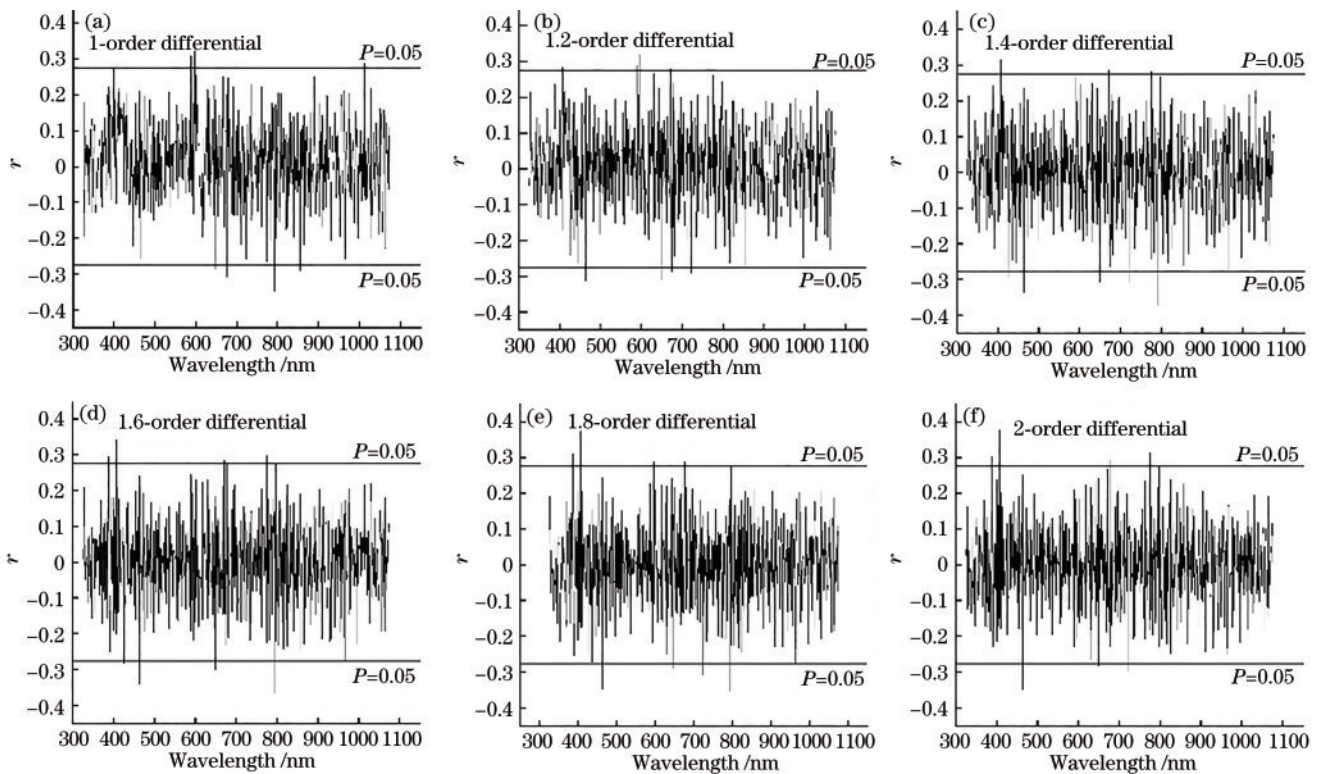


图 3 SOM 含量与光谱反射率变换形式的相关系数。(a) 1 阶微分；(b) 1.2 阶微分；(c) 1.4 阶微分；(d) 1.6 阶微分；(e) 1.8 阶微分；(f) 2 阶微分

Fig. 3 Correlation coefficient between SOM content and spectral reflectance transform form. (a) 1-order differential; (b) 1.2-order differential; (c) 1.4-order differential; (d) 1.6-order differential; (e) 1.8-order differential; (f) 2-order differential

3.4 模型建立与验证

基于分数阶微分光谱,采用 SVR、PLSR 和 RF 模型对 SOM 含量进行建模,结果如表 3 所示。由表 3 可知,运用 SVR 模型进行建模时 R^2 都超过 0.6,说明建模时的模型稳定性较好,其中 SVR_1、SVR_1.8 和 SVR_2 的 R^2 都超过 0.8,表明建模时模型稳定性更好,

且 RMSE 值也较低,模型预测准确性较高,RPD 都超过 2,说明对样本预测能力比较强;运用 SVR 模型进行验证时 R^2 都超过 0.8,可以看出验证集模型的稳定性良好, RMSE 也都很低,说明模型预测准确性较高, RPD 均超过 2,模型预测能力较强。通过对比得出, SVR 的 1 阶微分在建模和验证时取得了良好的效果。

表 3 SOM 含量建模和验证结果

Table 3 SOM content modeling and validation results

Model	Sample type	Model formula	R^2	RMSE	RPD
SVR_1	Calibration set	$y=0.76x+2.8583$	0.83	2.29	2.43
SVR_1.2		$y=0.7074x+3.5983$	0.73	2.84	1.96
SVR_1.4		$y=0.6341x+4.7963$	0.67	3.19	1.74
SVR_1.6		$y=0.7051x+3.9563$	0.71	3.01	1.85
SVR_1.8		$y=0.7537x+2.777$	0.81	2.45	2.27
SVR_2		$y=0.7488x+2.5789$	0.81	2.48	4.97
SVR_1	Validation set	$y=0.777x+3.0056$	0.82	1.75	3.38
SVR_1.2		$y=0.8659x+1.9667$	0.93	1.13	5.21
SVR_1.4		$y=0.897x+1.4525$	0.97	0.79	7.52
SVR_1.6		$y=0.9153x+1.274$	0.97	0.76	7.75
SVR_1.8		$y=0.9031x+1.5441$	0.96	0.86	6.83
SVR_2		$y=0.8639x+2.2584$	0.93	1.19	3.73
PLSR_1	Calibration set	$y=0.5492x+5.3037$	0.55	4.24	1.31
PLSR_1.2		$y=0.4062x+6.9854$	0.41	4.24	1.30
PLSR_1.4		$y=0.3676x+7.4394$	0.37	4.37	1.27
PLSR_1.6		$y=0.3553x+7.5838$	0.36	4.42	1.26
PLSR_1.8		$y=0.3697x+7.415$	0.37	4.37	1.27
PLSR_2		$y=0.3697x+7.4153$	0.37	4.37	1.05
PLSR_1	Validation set	$y=0.6591x+4.2127$	0.71	2.18	2.71
PLSR_1.2		$y=0.7094x+3.5908$	0.71	3.12	1.86
PLSR_1.4		$y=0.6275x+4.6023$	0.63	2.47	2.39
PLSR_1.6		$y=0.65x+4.3244$	0.65	2.39	2.47
PLSR_1.8		$y=0.6028x+4.9078$	0.60	2.55	2.32
PLSR_2		$y=0.6137x+4.7739$	0.61	2.52	2.09
RF_1	Calibration set	$y=0.6285x+4.3153$	0.82	2.61	2.13
RF_1.2		$y=0.5551x+5.2584$	0.92	2.60	2.14
RF_1.4		$y=0.5674x+5.1131$	0.91	2.58	2.16
RF_1.6		$y=0.5544x+5.2686$	0.88	2.70	2.06
RF_1.8		$y=0.5864x+4.9469$	0.91	2.50	2.22
RF_2		$y=0.6319x+4.7115$	0.80	2.71	2.05
RF_1	Validation set	$y=0.5873x+5.0345$	0.79	2.07	2.85
RF_1.2		$y=0.6418x+4.4054$	0.93	1.62	3.65
RF_1.4		$y=0.604x+4.953$	0.92	1.77	3.34
RF_1.6		$y=0.5824x+5.2598$	0.90	1.87	3.16
RF_1.8		$y=0.5654x+5.4647$	0.90	1.93	3.07
RF_2		$y=0.6048x+4.639$	0.86	1.88	3.14

运用 PLSR 模型进行建模时 R^2 都小于 0.5,表明建模模型的稳定性较差;RMSE 值也比较大,预测准确性较高;RPD 值都小于 1.4,表明该模型对样本预测能

力较差,效果不明显。运用 PLSR 模型进行验证时 R^2 都超过 0.6,说明验证集的模型运用较为稳定;RMSE 值也都较高,预测准确性较高;RPD 值均在 1.4~2 之

间,可以对样本进行粗略估计。通过对比得出,使用 PLSR 的 1 阶微分在建模和验证时都取得较好的效果。

运用 RF 模型进行建模和验证时 R^2 都高于 0.8,说明该模型的稳定性较好, RMSE 也都比较小,模型预测准确性较高, RPD 都超过了 2,表明模型对样本预测能力比较强。通过对比得出, RF 的 1.2 阶微分在建模和验证时效果明显。

综上所述,在使用 RF 模型的 1.2 阶微分时,建模和验证的 R^2 最大、RMSE 较小、RPD 较大,表明这 3 种模型中 RF 模型的效果最佳。为了更直观地对比 3 种模型建模效果,选择 3 种模型中最优的数学变换形式,如图 4 所示。由图 4 可知,无论是建模和验证样本,相比 SVR 和 PLSR, RF 的数据较为均匀地分布在 1:1 的直线两侧,与上述分析一致。




图 4 3 个模型中最优的数学变换形式的 SOM 结果图。(a) SVR 模型的 1 阶微分; (b) PLSR 模型的 1 阶微分; (c) RF 模型的 1.2 阶微分

Fig. 4 Optimal mathematical transformation form of SOM results in the three models. (a) 1-order differential of SVR model; (b) 1-order differential of PLSR model; (c) 1.2-order differential of RF model

4 讨 论

通过测定研究区域 SOM 含量与高光谱,从分数阶微分光谱处理和建模方法 2 个角度,尝试理解分数阶微分光谱处理方法和不同算法建模性能差别。

研究区域 SOM 含量较少,均值为 $11.96 \text{ g} \cdot \text{kg}^{-1}$,相比北疆的 SOM 含量略低^[22]。这与玉米提·买明^[23],唐梦迎等^[24]研究本研究区的 SOM 时所得结论基本一致。主要原因为:与北疆相比,南疆地处极度干旱荒漠地带,水分条件很差,不利于土壤腐殖质的积累,导致 SOM 含量低。

SOM 含量的高低对光谱反射率影响较大,通常土壤反射率和有机质含量呈负相关^[25-26]。本研究中有有机质含量高于 $6 \text{ g} \cdot \text{kg}^{-1}$ 时, SOM 对土壤光谱反射率的影响更显著,且土壤反射率与有机质含量呈负相关。这与周伟^[7]所得结论基本一致。但是,值得注意的是当有机质含量低于 $6 \text{ g} \cdot \text{kg}^{-1}$ 时, SOM 对土壤光谱反射率的影响不太明显。这是由于研究区属于典型的盐渍化地区,当 SOM 含量较低时,土壤含水量、盐分等对土壤光谱的影响大大增强^[27],敏感波段的选择存在一定困难。

与原始光谱相比,光谱微分技术有助于限制低频噪声对目标光谱的影响,能够提高敏感波长与 SOM 的相关性,但不合适的变换亦可使其相关性下降^[7]。尝试运用新的光谱处理方法进一步凸显土壤光谱间的细微差异,进而从整个光谱中得到贡献率较高的波长

变量,以建立适应性更佳的 SOM 估算模型。本研究表明,不同微分光谱变量的估测精度有所差异,土壤反射率经 1.2 阶微分变化后建立的 SOM 含量反演模型预测精度最高。这一分数阶微分变换方法与赵启东和国佳欣的结果存在一些差异。赵启东^[15]采用分数阶微分技术对土壤有机碳进行光谱估测时发现分数阶微分的处理效果要优于整数阶微分,并在 1.6 阶微分时取得了较好的结果。国佳欣^[26]发现对江西省的红壤 SOM 进行反演时,以 0.5 阶为步长,1.5 阶微分变换处效果最优。因此,在使用分数阶微分处理光谱数据时,选用的步长不同,可能造成微分变换形式的差异,从而影响模型的精度。今后将对此开展进一步研究。

高光谱遥感已经成为土壤理化参数快速无损监测的有效手段, RF 是一种比较新的机器学习模型,模型有泛化能力强、运行速度快、适用范围广等优点,在高光谱反演中展现出强大的性能^[27-28]。在分数阶微分处理方法的基础上引入 RF 算法,构建的模型精度更高,预测效果更好。近年来,深度学习(Deep learning, DL)发展迅速,在机器学习算法中脱颖而出^[30-31],深度学习是目前主流的机器学习方法,具有很强的学习和特征挖掘能力,在高光谱影像处理得到应用,但此方法对实测的地面高光谱反演研究还在探索阶段,因为深度学习算法需要大量的样本(土壤和光谱样本)来训练和检验模型,这个要求目前在实地采样还存在很多困难。然而,传统的机器学习方法稳定性较好,需要样本数量较少,因此在地面光谱反演时被广泛应用。该学

习算法目前对高光谱反演的数据量较大时效果较好, 不过也有研究探索在数据量较少的情况下(如几百个数据)构建基于高光谱的水稻叶片氮含量估计的深度森林模型^[30]。这也为今后的研究提供一种新的思路。

5 结 论

不同 SOM 水平下, 土壤光谱反射率不同, 但其反射率曲线整体变化趋势基本相同。高光谱反射率与 SOM 在多个波段相关性较好, 其中利用 RF 模型的 1.2 阶微分反演 SOM 效果最佳, 实测值和估测值的拟合最优。本研究结果为精准反演该地区的 SOM 提供了依据, 也对其他地区 SOM 反演具有一定的参考意义。

参 考 文 献

- [1] 李天杰, 赵焯, 张科利, 等. 土壤地理学[M]. 北京: 高等教育出版社, 2004.
Li T J, Zhao Y, Zhang K L, et al. Pedogeography[M]. Beijing: Higher Education Press, 2004.
- [2] Chen Y, Wang J L, Liu G J, et al. Hyperspectral estimation model of forest soil organic matter in northwest Yunnan Province, China[J]. Forests, 2019, 10(3): 217.
- [3] Fu C B, Xiong H G, Tian A H. Study on the effect of fractional derivative on the hyperspectral data of soil organic matter content in arid region[J]. Journal of Spectroscopy, 2019, 2019: 7159317.
- [4] 赵明松, 谢毅, 陆龙妹, 等. 基于高光谱特征指数的土壤有机质含量建模[J]. 土壤学报, 2021, 58(1): 42-54.
Zhao M S, Xie Y, Lu L M, et al. Modeling for soil organic matter content based on hyperspectral feature indices[J]. Acta Pedologica Sinica, 2021, 58(1): 42-54.
- [5] 韩春兰, 刘金宝, 付小梅, 等. 粗面岩质火山碎屑物发育土壤有机质含量的高光谱特征与建模[J]. 土壤通报, 2017, 48(1): 39-44.
Han C L, Liu J B, Fu X M, et al. Hyperspectrum characteristics and modeling of organic matter content in soils developed from trachytic tephra[J]. Chinese Journal of Soil Science, 2017, 48(1): 39-44.
- [6] 于雷, 洪永胜, 耿雷, 等. 基于偏最小二乘回归的土壤有机质含量高光谱估算[J]. 农业工程学报, 2015, 31(14): 103-109.
Yu L, Hong Y S, Geng L, et al. Hyperspectral estimation of soil organic matter content based on partial least squares regression[J]. Transactions of the Chinese Society of Agricultural Engineering, 2015, 31(14): 103-109.
- [7] 周伟, 谢利娟, 杨晗, 等. 基于高光谱的三江源区土壤有机质含量反演[J]. 土壤通报, 2021, 52(3): 564-574.
Zhou W, Xie L J, Yang H, et al. Hyperspectral inversion of soil organic matter content in the three-rivers source region[J]. Chinese Journal of Soil Science, 2021, 52(3): 564-574.
- [8] 陈昊宇, 杨光, 韩雪莹, 等. 基于连续小波变换的土壤有机质含量高光谱反演[J]. 中国农业科技导报, 2021, 23(5): 132-142.
Chen H Y, Yang G, Han X Y, et al. Hyperspectral inversion of soil organic matter content based on continuous wavelet transform[J]. Journal of Agricultural Science and Technology, 2021, 23(5): 132-142.
- [9] 尚天浩, 毛鸿欣, 张俊华, 等. 基于 PCA 敏感波段筛选与 SVM 建模的银川平原土壤有机质高光谱估算[J]. 生态学杂志, 2021(12): 4128-4136.
Shang T H, Mao H X, Zhang J H, et al. Hyperspectral estimation of soil organic matter content in Yinchuan plain, China based on PCA sensitive band screening and SVM modeling[J]. Chinese Journal of Ecology, 2021(12): 4128-4136.
- [10] 李厚萱, 王翔, 于滋洋, 等. 不同测试条件对土壤有机质光谱预测模型精度的影响[J]. 土壤通报, 2020, 51(6): 1359-1365.
Li H X, Wang X, Yu Z Y, et al. Effects of different testing conditions on the accuracy of soil organic matter spectral prediction model[J]. Chinese Journal of Soil Science, 2020, 51(6): 1359-1365.
- [11] 吾木提·艾山江, 买买提·沙吾提, 马春玥. 基于分数阶微分和连续投影算法-反向传播神经网络的小麦叶片含水量高光谱估算[J]. 激光与光电子学进展, 2019, 56(15): 153002.
Umut H, Mamat S, Ma C Y. Hyperspectral estimation of wheat leaf water content using fractional differentials and successive projection algorithm-back propagation neural network[J]. Laser & Optoelectronics Progress, 2019, 56(15): 153002.
- [12] 田安红, 赵俊三, 张顺吉, 等. 基于分数阶微分的盐渍土电导率高光谱估算研究[J]. 中国生态农业学报, 2020, 28(4): 599-607.
Tian A H, Zhao J S, Zhang S J, et al. Hyperspectral estimation of saline soil electrical conductivity based on fractional derivative[J]. Chinese Journal of Eco-Agriculture, 2020, 28(4): 599-607.
- [13] Wang X P, Zhang F, Kung H T, et al. New methods for improving the remote sensing estimation of soil organic matter content (SOMC) in the Ebinur Lake Wetland National Nature Reserve (ELWNNR) in northwest China [J]. Remote Sensing of Environment, 2018, 218: 104-118.
- [14] 赵慧, 李新国, 靳万贵, 等. 基于分数阶微分的博斯腾湖湖滨绿洲土壤电导率高光谱估算[J]. 甘肃农业大学学报, 2021, 56(1): 118-125.
Zhao H, Li X G, Jin W G, et al. Fractional differential based hyperspectral estimation model of soil electrical conductivity of Bosten Lake oasis[J]. Journal of Gansu Agricultural University, 2021, 56(1): 118-125.
- [15] 赵启东, 葛翔宇, 丁建丽, 等. 结合分数阶微分技术与机器学习算法的土壤有机碳含量光谱估测[J]. 激光与光电子学进展, 2020, 57(15): 153001.
Zhao Q D, Ge X Y, Ding J L, et al. Combination of fractional order differential and machine learning algorithm for spectral estimation of soil organic carbon content[J]. Laser & Optoelectronics Progress, 2020, 57(15): 153001.

- [16] 鲁如坤. 土壤农业化学分析方法[M]. 北京: 中国农业科技出版社, 2000: 106-109.
Lu R K. Agricultural chemical analysis method of soil [M]. China Agriculture Sciencetech Press, 2000: 106-109.
- [17] 依尔夏提·阿不来提, 白灯莎·买买提艾力, 买买提·沙吾提, 等. 基于高光谱和BP神经网络的棉花冠层叶绿素含量联合估算[J]. 光学学报, 2019, 39(9): 0930003.
Ershat A, Baidengsha M, Mamat S, et al. Combined estimation of chlorophyll content in cotton canopy based on hyperspectral parameters and back propagation neural network[J]. Acta Optica Sinica, 2019, 39(9): 0930003.
- [18] Collobert R, Bengio S. SVM Torch: support vector machines for large-scale regression problems[J]. Journal of Machine Learning Research, 2001, 1: 143-160.
- [19] Wold S, Sjöström M, Eriksson L. PLS-regression: a basic tool of chemometrics[J]. Chemometrics and Intelligent Laboratory Systems, 2001, 58(2): 109-130.
- [20] Viscarra Rossel R A, McGlynn R N, McBratney A B. Determining the composition of mineral-organic mixes using UV-vis-NIR diffuse reflectance spectroscopy[J]. Geoderma, 2006, 137(1/2): 70-82.
- [21] 全国第二次土壤普查养分分级标准[EB/OL]. (2012-05-10)[2022-02-05]. <http://wenku.baidu.com/view/1242f6ef856a2561252d36f6e.html>.
Nutrient classification standard of the second national soil survey[EB/OL]. (2012-05-10)[2022-02-05]. <http://wenku.baidu.com/view/1242f6ef856a2561252d36f6e.html>.
- [22] 单海斌, 蒋平安, 颜安, 等. 基于高光谱数据的北疆绿洲农田灰漠土有机质反演[J]. 农业资源与环境学报, 2018, 35(3): 276-282.
Shan H B, Jiang P G, Yan A, et al. Inversion of organic matter content in grey desert soil of northern Xinjiang oasis farmland based on hyper-spectral data[J]. Journal of Agricultural Resources and Environment, 2018, 35(3): 276-282.
- [23] 玉米提·买明, 王雪梅. 塔里木盆地北缘荒漠土壤有机质含量的高光谱估测[J]. 中国土壤与肥料, 2021(4): 318-326.
Yumiti M, Wang X M. Hyperspectral estimation of desert soil organic matter content in the northern margin of Tarim Basin[J]. Soil and Fertilizer Sciences in China, 2021(4): 318-326.
- [24] 唐梦迎, 丁建丽, 夏楠, 等. 干旱区典型绿洲土壤有机质含量分布特征及其影响因素[J]. 土壤学报, 2017, 54(3): 759-766.
Tang M Y, Ding J L, Xia N, et al. Distribution of soil organic matter content and its affecting factors in oases typical of arid region[J]. Acta Pedologica Sinica, 2017, 54(3): 759-766.
- [25] Al-Abbas A H, Swain P H, Baumgardner M F. Relating organic matter and clay content to the multispectral radiance of soils[J]. Soil Science, 1972, 114(6): 477-485.
- [26] 国佳欣, 赵小敏, 郭熙, 等. 基于PLSR-BP复合模型的红壤有机质含量反演研究[J]. 土壤学报, 2020, 57(3): 636-645.
Guo J X, Zhao X M, Guo X, et al. Inversion of organic matter content in red soil based on PLSR-BP composite model[J]. Acta Pedologica Sinica, 2020, 57(3): 636-645.
- [27] Zhou W, Yang H, Xie L J, et al. Hyperspectral inversion of soil heavy metals in Three-River Source Region based on random forest model[J]. CATENA, 2021, 202: 105222.
- [28] 白婷, 丁建丽, 王敬哲. 基于机器学习算法的土壤有机质质量比估算[J]. 排灌机械工程学报, 2020, 38(8): 829-834.
Bai T, Ding J L, Wang J Z. Estimation of soil organic matter content based on machine learning[J]. Journal of Drainage and Irrigation Machinery Engineering, 2020, 38(8): 829-834.
- [29] 杨莎, 王超, 杨武德, 等. 预处理对土壤有机质光谱估算的影响[J]. 山西农业科学, 2020, 48(10): 1637-1640, 1645.
Yang S, Wang C, Yang W D, et al. Effect of pretreatments on spectral estimation of soil organic matter (SOM) [J]. Journal of Shanxi Agricultural Sciences, 2020, 48(10): 1637-1640, 1645.
- [30] 李金敏, 陈秀青, 杨琦, 等. 基于高光谱的水稻叶片氮含量估计的深度森林模型研究[J]. 作物学报, 2021, 47(7): 1342-1350.
Li J M, Chen X Q, Yang Q, et al. Deep learning models for estimation of paddy rice leaf nitrogen concentration based on canopy hyperspectral data[J]. Acta Agronomica Sinica, 2021, 47(7): 1342-1350.
- [31] 岳学军, 凌康杰, 王林惠, 等. 基于高光谱和深度迁移学习的柑橘叶片钾含量反演[J]. 农业机械学报, 2019, 50(3): 186-195.
Yue X J, Ling K J, Wang L H, et al. Inversion of potassium content for citrus leaves based on hyperspectral and deep transfer learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(3): 186-195.